



Klasifikasi Kategori Berita Menggunakan Algoritma Naive Bayes pada Dataset Berita Online

Putri Salsa Nabila

Ilmu Komputer, Sains dan Teknologi, Universitas Islam Negeri Sumatera Utara

putri0701232090@uinsu.ac.id

Abstrak

Penelitian ini bertujuan untuk melakukan klasifikasi kategori berita secara otomatis dengan menggunakan algoritma Naive Bayes pada AG News Classification Dataset. Dataset yang digunakan dalam penelitian ini berjumlah 7.533 berita yang terbagi ke dalam empat kategori, yaitu dunia, olahraga, bisnis, serta sains atau teknologi. Penggunaan klasifikasi otomatis diharapkan dapat membantu proses pengelompokan berita berdasarkan kategori secara lebih cepat, sistematis, dan terstruktur. Tahapan penelitian meliputi pengumpulan data, preprocessing teks, pembentukan model klasifikasi, serta evaluasi terhadap kinerja model. Tahap preprocessing dilakukan melalui beberapa proses, yaitu tokenisasi, perubahan seluruh huruf menjadi lowercase, penghapusan stopword, dan pembobotan kata untuk mengubah data teks menjadi bentuk yang dapat diproses oleh algoritma. Tahapan tersebut dilakukan untuk mengurangi unsur yang kurang relevan pada teks serta menghasilkan data yang lebih sesuai untuk proses klasifikasi. Selanjutnya, model klasifikasi dibangun menggunakan bahasa pemrograman Python melalui Google Colab. Kinerja model dievaluasi menggunakan confusion matrix untuk memperoleh nilai akurasi, precision, dan recall pada setiap kategori berita. Evaluasi dilakukan untuk mengetahui kemampuan model dalam mengenali dan membedakan berita berdasarkan kategori yang telah ditentukan. Hasil penelitian menunjukkan bahwa algoritma Naive Bayes mampu melakukan klasifikasi berita ke dalam empat kategori dengan cukup baik. Hasil tersebut menunjukkan bahwa metode Naive Bayes dapat digunakan sebagai salah satu pendekatan dalam klasifikasi teks, khususnya untuk membantu proses pengelompokan berita secara otomatis berdasarkan kategori yang telah ditentukan.

Kata kunci: Klasifikasi Teks, Naive Bayes, Teks Mining, Berita Online

Abstract

This study aims to automatically classify news categories using the Naive Bayes algorithm on the AG News Classification Dataset. The dataset used in this study consists of 7,533 news articles divided into four categories: world, sports, business, and science or technology. The use of automatic classification is expected to help the process of grouping news articles based on their categories in a faster, systematic, and structured manner. The research stages include data collection, text preprocessing, classification model development, and model performance evaluation. The preprocessing stage consists of several processes, including tokenization, converting all letters to lowercase, removing stopwords, and word weighting to transform text data into a form that can be processed by the algorithm. These processes are conducted to reduce irrelevant elements in the text and produce data that are more suitable for the classification process. Furthermore, the classification model is developed using the Python programming language through Google Colab. Model performance is evaluated using a confusion matrix to obtain accuracy, precision, and recall values for each news category. The evaluation is conducted to determine the model's ability to recognize and distinguish news articles based on the predetermined categories. The results show that the Naive Bayes algorithm is able to classify news articles into four categories with satisfactory performance. These results indicate that the Naive Bayes method can be used as an approach for text classification, particularly to assist the automatic grouping of news articles based on predetermined categories.

Keywords: Text Classification, Naive Bayes, Text Mining, Online News.

1. Pendahuluan

Perkembangan teknologi informasi dan internet telah meningkatkan jumlah berita *online* yang tersedia secara cepat dan masif. Banyaknya data berita yang dihasilkan setiap hari menimbulkan tantangan dalam proses pengelompokan informasi secara manual, terutama ketika volume data semakin besar. Oleh karena itu, diperlukan metode otomatis untuk membantu klasifikasi teks guna meningkatkan efektivitas proses pengelolaan berita (Habib et al., 2022).

Klasifikasi berita adalah salah satu contoh penerapan *text mining* yang berguna untuk mengelompokkan dokumen berita ke dalam kategori tertentu, misalnya dunia, olahraga, bisnis, serta sains atau teknologi. Dalam praktiknya, berbagai algoritma *Machine Learning* sudah banyak dimanfaatkan untuk mendukung proses klasifikasi secara otomatis. Salah satu algoritma yang populer adalah Naïve Bayes, yang dikenal karena pendekatannya yang simpel, efisien, serta kemampuannya dalam menangani klasifikasi dokumen teks dengan hasil yang cukup baik (Prasetya, 2022). Sejumlah penelitian sebelumnya menunjukkan bahwa algoritma *Naïve Bayes* bekerja dengan cukup baik pada berbagai kasus klasifikasi teks. Penelitian yang dilakukan oleh Sukriadi, Ismail, dan Andzar membuktikan bahwa metode ini dapat diterapkan secara efektif dalam proses klasifikasi teks (Andzar, 2023).

Hasil serupa juga ditemukan dalam penelitian lain, yang menunjukkan bahwa *Naïve Bayes* mampu digunakan untuk klasifikasi dokumen teks dengan hasil yang memuaskan (Lestari et al., 2023). Dalam ranah klasifikasi berita, studi-studi terdahulu juga memperlihatkan bahwa algoritma *Naïve Bayes* memberikan performa yang baik. Berdasarkan temuan-temuan tersebut, metode *Naïve Bayes* dinilai memiliki potensi yang baik untuk diterapkan dalam klasifikasi kategori berita pada penelitian ini (Akbar & Defit, 2024).

Dalam proses klasifikasi teks, tahap *preprocessing* memegang peranan penting untuk meningkatkan kualitas data sebelum masuk ke tahap klasifikasi. Langkah-langkah seperti tokenisasi, mengubah huruf menjadi kecil (*lowercase*), serta menghilangkan kata-kata umum (*stopword*) digunakan untuk membersihkan dan menyiapkan data agar lebih relevan bagi proses klasifikasi (Purnama & Sipayung, 2025). Selain itu, pemberian bobot pada kata juga diterapkan agar representasi data menjadi lebih terstruktur, sehingga dapat mendukung jalannya klasifikasi secara lebih optimal (Ionendri et al., 2025a). (Pranata et al., 2024) menerapkan *preprocessing* dan pembobotan TF-IDF sebelum melakukan klasifikasi menggunakan Naïve Bayes. Pembobotan TF-IDF digunakan untuk memberikan nilai terhadap kata berdasarkan tingkat kepentingannya dalam dokumen sehingga data teks dapat direpresentasikan dalam bentuk numerik.

Penggunaan TF-IDF bersama Multinomial Naïve Bayes juga telah diterapkan dalam penelitian klasifikasi berita. (Agape & Giri, 2025) menggunakan Multinomial Naïve Bayes dengan pembobotan TF-IDF dan seleksi fitur Chi-Squared untuk klasifikasi berita. (Ionendri et al., 2025b) pada penelitian ini menerapkan TF-IDF dan Multinomial Naïve Bayes pada klasifikasi berita dengan beberapa kategori. Berdasarkan penelitian ini menunjukkan bahwa Naïve Bayes dapat digunakan untuk mengklasifikasikan berita online melalui tahapan *preprocessing* dan evaluasi menggunakan confusion matrix (Amri et al., 2025). Selain itu pada penelitian zhang mengkaji penggunaan Naïve Bayes dan TF-IDF dalam klasifikasi berita serta menunjukkan bahwa kombinasi fitur berbasis TF-IDF dapat digunakan sebagai bagian dari proses klasifikasi berita (Zhang, 2025).

Selain penelitian yang telah dibahas, penerapan algoritma Naïve Bayes pada klasifikasi teks juga telah dilakukan pada berbagai jenis data berita dan dokumen. (Tejawati et al., 2023) membahas klasifikasi isi berita dengan membandingkan metode K-Nearest Neighbor dan Naïve Bayes serta menggunakan tahapan pengolahan teks dan evaluasi menggunakan confusion matrix. (Arsyad et al., 2023) menerapkan Multinomial Naïve Bayes untuk mendeteksi konten hoaks pada media berita Indonesia, yang menunjukkan penggunaan model Multinomial Naïve Bayes sebagai salah satu pendekatan dalam pengolahan dan klasifikasi teks berita. (Mardiana & Prihartono, 2025) menggunakan TF-IDF sebagai pembobotan fitur dan Naïve Bayes untuk mengklasifikasikan judul berita online berbahasa Indonesia, dengan data yang berasal dari beberapa portal berita nasional. Sementara itu, (Afandi & Kurniawan, 2025) menerapkan Naïve Bayes untuk klasifikasi teks pada komentar pengguna dengan tahapan pengolahan data teks sebelum proses klasifikasi. Penelitian-penelitian tersebut memperlihatkan bahwa Naïve Bayes dapat diterapkan pada berbagai bentuk data teks dengan dukungan tahapan *preprocessing* dan representasi fitur untuk menghasilkan data yang dapat digunakan dalam proses klasifikasi.

Berdasarkan beberapa penelitian tersebut, algoritma Multinomial Naïve Bayes digunakan dalam penelitian ini untuk melakukan klasifikasi kategori berita pada AG News Classification Dataset. Dataset yang digunakan terdiri dari 7.533 berita yang terbagi ke dalam empat kategori, yaitu dunia, olahraga, bisnis, serta sains atau teknologi. Tahapan penelitian meliputi pengumpulan data, pemahaman data, *preprocessing* teks, penggabungan atribut Title dan Description, transformasi teks menggunakan TF-IDF dengan unigram dan bigram, pembagian data, pembentukan model Multinomial Naïve Bayes, prediksi, dan evaluasi model. Seluruh proses penelitian dilakukan menggunakan bahasa pemrograman Python melalui Google Colab sehingga tahapan pengolahan data dan pembentukan model dapat dilakukan secara terstruktur dan konsisten.

1.1. Klasifikasi Teks

Klasifikasi teks adalah salah satu pendekatan dalam *data mining* yang dipakai untuk mengelompokkan dokumen teks ke dalam kategori tertentu secara otomatis berdasarkan isi dokumen itu sendiri. Proses pengelompokannya dilakukan dengan bantuan algoritma *machine learning* untuk mengenali pola kata yang ada dalam data teks. Teknik ini banyak diterapkan di berbagai bidang, seperti penyaringan email spam, analisis sentimen, pengelompokan berita, hingga sistem rekomendasi. Dalam pelaksanaannya, dokumen teks terlebih dahulu diubah ke dalam bentuk numerik supaya bisa diproses oleh komputer menggunakan metode tertentu (Hanum et al., 2024). Dalam penelitian ini, klasifikasi teks dimanfaatkan untuk mengelompokkan berita ke dalam kategori tertentu. Berkat adanya teknik ini, proses pengelompokan data berita bisa berjalan lebih cepat dan efisien jika dibandingkan dengan cara manual, terutama saat jumlah data yang dihadapi sangat besar.

1.2. Data Mining

Data mining merupakan proses menggali informasi penting dari kumpulan data berukuran besar guna menemukan pola, keterkaitan, maupun pengetahuan baru yang sebelumnya belum diketahui. Proses ini menjadi salah satu komponen kunci dalam perkembangan teknologi informasi karena mampu mendukung pengambilan keputusan berdasarkan data yang tersedia (Hendri Hartono, 2023). Secara umum, tahapan dalam *data mining* meliputi pengumpulan data, pemrosesan awal data (*preprocessing*), pemilihan metode, proses pemodelan, hingga evaluasi terhadap hasil yang diperoleh. Dalam penelitian ini, *data mining* digunakan untuk mengolah *dataset* berita agar proses klasifikasi dapat berjalan secara otomatis dengan memanfaatkan algoritma *Naïve Bayes*.

1.3. Naïve Bayes

Naïve Bayes adalah metode klasifikasi yang berbasis pada perhitungan probabilitas, di mana Teorema Bayes dijadikan sebagai landasan utama dalam proses perhitungannya. Cara kerja metode ini adalah dengan menghitung seberapa besar kemungkinan suatu data termasuk ke dalam kelas tertentu, berdasarkan fitur-fitur yang dimilikinya. Salah satu asumsi utama dari *Naïve Bayes* adalah bahwa setiap fitur bersifat independen atau tidak saling bergantung satu sama lain (Rozi et al., 2023).

Metode *Naïve Bayes* cukup populer digunakan dalam klasifikasi teks karena selain proses perhitungannya sederhana, akurasi juga tergolong baik. Algoritma ini juga masih bekerja secara efektif pada data yang memiliki dimensi tinggi, seperti dokumen teks. Berikut adalah persamaan dasar dari Teorema Bayes:

$$P(H | X) = \frac{P(X | H) P(H)}{P(X)}$$

Keterangan:

$P(H | X)$ = probabilitas hipotesis H terjadi jika diketahui kondisi X

$P(X | H)$ = probabilitas kemunculan X jika hipotesis H benar

$P(H)$ = probabilitas awal (prior) dari hipotesis H

$P(X)$ = probabilitas kemunculan data X

Dalam penelitian ini, *Naïve Bayes* digunakan untuk menentukan kategori suatu berita berdasarkan kata-kata yang terdapat di dalam teks berita tersebut.

Preprocessing teks adalah langkah awal dalam pemrosesan data teks yang berguna untuk membersihkan data agar lebih mudah diolah oleh algoritma *machine learning*. Tahap ini sangat krusial karena kualitas data yang digunakan akan sangat memengaruhi hasil akhir dari klasifikasi (Mardiana et al., 2025). Beberapa tahapan *preprocessing* teks yang umum dipakai antara lain: *Case folding*, yakni mengubah semua huruf dalam teks menjadi huruf kecil. *Tokenizing*, yaitu memecah kalimat menjadi potongan kata-kata. *Stopword removal*, yaitu menghapus kata-kata yang tidak memiliki makna penting, misalnya “dan”, “yang”, atau “di”. *Stemming*, yaitu mengubah kata ke bentuk dasarnya. Dengan adanya *preprocessing*, data teks menjadi lebih terstruktur sehingga dapat membantu meningkatkan performa proses klasifikasi

Python adalah bahasa pemrograman yang cukup populer di bidang *data science* dan *machine learning*. Hal ini tidak lepas dari sintaksnya yang sederhana serta dukungan berbagai pustaka untuk pengolahan data, seperti Pandas, NumPy, Scikit-learn, dan Matplotlib. Dalam penelitian ini, Python dimanfaatkan untuk melakukan *preprocessing* data, proses klasifikasi dengan algoritma *Naïve Bayes*, serta evaluasi terhadap model yang dibangun. Sementara itu, Google Colab dipilih sebagai lingkungan pengembangan karena berbasis *cloud*, sehingga tidak menuntut spesifikasi komputer yang tinggi dan bisa dijalankan secara *online* cukup lewat *browser*

Pada penelitian ini, *dataset* yang dipakai adalah *AG News Classification Dataset*. *Dataset* ini berisi kumpulan berita yang sudah dikelompokkan ke dalam beberapa kategori, antara lain dunia, olahraga, bisnis, serta sains dan teknologi. Karena struktur datanya jelas dan mudah diolah, *dataset* ini cukup populer digunakan dalam penelitian klasifikasi teks (Selawati, 2025). Jumlah data yang digunakan sebanyak 7.533, dengan masing-masing data terdiri dari teks berita dan label kategorinya. *Dataset* ini kemudian dipakai sebagai data latih maupun data uji dalam proses klasifikasi menggunakan metode *Naïve Bayes*. Berkat adanya *dataset* tersebut, model dapat mempelajari pola kata dari setiap kategori berita, sehingga mampu melakukan prediksi kategori secara otomatis

2. Metode Penelitian

2.1. Pengumpulan Data

Pada penelitian ini, data yang digunakan berupa dataset berita yang diperoleh dari situs Kaggle sebagai salah satu platform penyedia dataset publik yang banyak digunakan dalam penelitian *data mining* dan *machine learning*. *Dataset* tersebut diunduh dari situs <http://www.kaggle.com> kemudian disimpan dalam format *file* CSV.

Proses pengolahan data dilakukan menggunakan Google Colab dengan menghubungkan ke Google Drive sebagai media penyimpanan. Selanjutnya, dataset diakses dari folder Google Drive. Dataset dibaca menggunakan library *pandas* dan ditampilkan sebagian untuk memastikan data berhasil dimuat.

Pseudocode Pengumpulan Data

Input: Dataset berita online

Output: Dataset berita dalam format CSV

Mulai

Siapkan dataset berita dari Kaggle

Unduh dataset dalam format CSV

Hubungkan Google Colab dengan Google Drive

Simpan dataset pada Google Drive

Akses dataset dari folder Google Drive

Baca dataset menggunakan library *pandas*

Tampilkan sebagian data

Pastikan dataset berhasil dimuat

Selesai

2.2. Pemahaman Data (*Data Understanding*)

Tabel 2.1 struktur *dataset* yang digunakan:

No	Atribut	Deskripsi
1	Title	Judul berita
2	Description	Isi/deskripsi berita
3	Class Index	Label kategori berita

Tahap pemahaman data dilakukan untuk mengetahui struktur dan karakteristik dataset sebelum dilakukan proses *preprocessing*. Dataset yang digunakan memiliki tiga atribut utama, yaitu Title, Description, dan Class Index. Atribut Title berisi judul berita, Description berisi isi atau deskripsi berita, sedangkan Class Index digunakan sebagai label kategori berita. Tahap ini dilakukan untuk memahami karakteristik data sebelum masuk ke proses *preprocessing*.

Pseudocode Pemahaman Data

Input: Dataset berita online

Output: Informasi struktur dan atribut dataset

Mulai
Baca dataset berita
Periksa struktur dataset
Identifikasi atribut yang tersedia
Identifikasi atribut Title sebagai judul berita
Identifikasi atribut Description sebagai isi atau deskripsi berita
Identifikasi atribut Class Index sebagai label kategori berita
Pahami isi dari setiap atribut
Selesai

2.3. Preprocessing Data (Penggabungan Teks)

Preprocessing dilakukan sebagai tahap awal untuk membersihkan dan menyiapkan data teks sebelum digunakan dalam proses klasifikasi. Pada penelitian ini, preprocessing meliputi penggabungan teks, pembersihan teks, perubahan huruf menjadi lowercase, penghapusan karakter selain huruf, tokenisasi sederhana, dan penghapusan stopwords. Tahapan tersebut dilakukan agar data teks menjadi lebih terstruktur sebelum masuk ke proses klasifikasi.

Kolom Title dan Description digabungkan untuk menghasilkan teks yang lebih lengkap sebagai input model. Penggabungan ini dilakukan dengan menggabungkan isi judul dan deskripsi berita menjadi satu atribut teks.

Pseudocode Penggabungan Teks

Input: Title dan Description

Output: Text

Mulai
Ambil nilai pada kolom Title
Ambil nilai pada kolom Description
Gabungkan Title dan Description dengan spasi
Simpan hasil penggabungan sebagai atribut Text
Selesai

2.4. Preprocessing Data (Pembersihan Teks)

Tahapan pembersihan teks meliputi mengubah teks menjadi huruf kecil atau *case folding*, menghapus karakter selain huruf, melakukan tokenisasi sederhana, dan menghapus stopwords. Tahapan ini dilakukan untuk membersihkan teks sebelum digunakan dalam proses transformasi data.

Pseudocode Pembersihan Teks

Input: Text

Output: Clean_Text

Mulai
Ambil setiap data pada atribut Text
Ubah seluruh huruf menjadi huruf kecil
Hapus karakter selain huruf
Pecah teks menjadi token
Hapus token yang termasuk dalam stopwords
Gabungkan kembali token yang tersisa
Simpan hasil sebagai Clean_Text

Selesai

2.5. Tranformasi Data

TF-IDF digunakan untuk mengubah teks menjadi representasi numerik. Pada penelitian ini digunakan $ngram_range=(1,2)$ yang memungkinkan model mempertimbangkan unigram dan bigram. Unigram merupakan satu kata, sedangkan bigram merupakan dua kata yang digunakan sebagai fitur dalam proses klasifikasi.

Pseudocode Transformasi TF-IDF

Input: Clean_Text

Output: Matriks fitur TF-IDF

Mulai

Ambil seluruh data Clean_Text

Tentukan rentang n-gram dari 1 sampai 2

Bentuk fitur unigram

Bentuk fitur bigram

Hitung nilai TF

Hitung nilai IDF

Hitung nilai TF-IDF

Bentuk matriks fitur TF-IDF

Selesai

2.6. Penentuan Model

Kolom Class Index digunakan sebagai target atau label dalam proses klasifikasi. Label tersebut digunakan sebagai acuan kategori berita dalam proses pembentukan model klasifikasi

Pseudocode Penentuan Label

Input: Dataset berita

Output: Label Y

Mulai

Ambil nilai pada kolom Class Index

Tetapkan Class Index sebagai target atau label

Simpan label sebagai Y

Selesai.

2.7. Pembagian Data

Data dibagi menjadi data latih dan data uji dengan proporsi 80 persen untuk data latih dan 20 persen untuk data uji. Data latih digunakan dalam proses pembentukan model, sedangkan data uji digunakan untuk proses prediksi dan evaluasi model.

Pseudocode Pembagian Data

Input: Matriks fitur X dan label Y

Output: Data latih dan data uji

Mulai

Tentukan proporsi data latih sebesar 80 persen

Tentukan proporsi data uji sebesar 20 persen

Bagi X dan Y menjadi data latih dan data uji

Simpan data latih sebagai X_train dan Y_train

Simpan data uji sebagai X_test dan Y_test

Selesai

2.8. Pembuatan Model Multinomial Naïve Bayes

Model klasifikasi yang digunakan dalam penelitian ini adalah Multinomial Naïve Bayes. Model dibangun menggunakan data latih yang terdiri dari fitur hasil transformasi TF-IDF dan label kategori berita. Proses pelatihan dilakukan agar model dapat mempelajari pola data dari setiap kategori berita.

Pseudocode Pembuatan Model Multinomial Naïve Bayes

Input: X_train dan Y_train
Output: Model Multinomial Naïve Bayes

Mulai
Inisialisasi model Multinomial Naïve Bayes
Masukkan X_train sebagai data latih
Masukkan Y_train sebagai label data latih
Lakukan proses pembelajaran model
Simpan model hasil pelatihan
Selesai

2.9. Prediksi Data

Setelah model selesai dilatih, data uji digunakan untuk melakukan proses prediksi. Data X_test dimasukkan ke dalam model untuk menghasilkan kategori berita yang diprediksi.

Pseudocode Prediksi Data

Input: Model Naïve Bayes dan X_test
Output: Y_pred

Mulai
Masukkan X_test ke dalam model
Lakukan proses prediksi
Tentukan kategori untuk setiap data uji
Simpan hasil prediksi sebagai Y_pred
Selesai

2.10. Evaluasi Model

Evaluasi dilakukan untuk mengetahui performa model klasifikasi yang telah dibangun. Evaluasi menggunakan accuracy, classification report, dan confusion matrix. Classification report digunakan untuk memperoleh nilai precision, recall, dan F1-score setiap kelas, sedangkan confusion matrix digunakan untuk melihat hasil klasifikasi pada masing-masing kategori.

Pseudocode Evaluasi Model

Input: Y_test dan Y_pred
Output: Accuracy, Classification Report, Confusion Matrix

Mulai
Bandingkan Y_test dengan Y_pred
Hitung nilai accuracy
Hitung precision setiap kelas
Hitung recall setiap kelas
Hitung F1-score setiap kelas
Bentuk classification report


Bentuk confusion matrix
Tampilkan hasil evaluasi
Selesai

3. Hasil dan Pembahasan

Hasil evaluasi model Multinomial Naïve Bayes diperoleh dari pengujian terhadap data berita yang telah melalui tahap *preprocessing* dan pembobotan menggunakan TF-IDF dengan kombinasi *unigram* dan *bigram*. Evaluasi dilakukan menggunakan beberapa metrik, yaitu *accuracy*, *precision*, *recall*, dan *F1-score*. Hasil evaluasi digunakan untuk mengetahui kemampuan model dalam mengenali dan membedakan berita berdasarkan kategori yang telah ditentukan.

Pembahasan adalah penjelasan dasar, hubungan dan generalisasi yang ditunjukkan oleh hasil. Uraianya menjawab pertanyaan penelitian. Jika ada hasil yang meragukan maka tampilkan secara objektif.

3.1. Hasil Evaluasi Model



Gambar 3.1 Hasil evaluasi model

Berdasarkan hasil evaluasi, model memperoleh nilai akurasi sebesar 87,96%. Hasil tersebut menunjukkan bahwa sebagian besar data pengujian dapat diklasifikasikan ke dalam kategori yang sesuai. Namun, akurasi tidak dapat digunakan sebagai satu-satunya dasar untuk menilai kinerja model karena jumlah dan karakteristik data pada setiap kelas dapat memengaruhi nilai tersebut. Oleh karena itu, evaluasi juga dilakukan menggunakan *precision*, *recall*, dan *F1-score* pada setiap kelas.

3.2. Akurasi Model

Tabel 3.2 Tampilan akurasi model

Metrik	Nilai
Accuracy	0.8796

Nilai akurasi sebesar 87,96% menunjukkan bahwa model mampu memberikan prediksi yang benar pada sebagian besar data pengujian. Capaian ini menunjukkan bahwa kombinasi TF-IDF dengan *unigram* dan *bigram* dapat memberikan representasi fitur yang cukup informatif untuk proses klasifikasi berita. Penggunaan *unigram* membantu model mengenali kata secara individual, sedangkan *bigram* memungkinkan model mempertimbangkan pasangan kata yang muncul secara berurutan.

Meskipun demikian, nilai akurasi 87,96% masih menunjukkan bahwa terdapat sebagian data yang belum dapat diklasifikasikan dengan tepat. Kesalahan tersebut dapat terjadi ketika berita dari dua kategori memiliki kosakata atau konteks pembahasan yang serupa. Kondisi ini menunjukkan bahwa representasi berbasis frekuensi kata belum sepenuhnya mampu memahami makna atau hubungan semantik antar kata dalam suatu berita.

3.3. Classification Report

Tabel 3. Klasifikasi report

Kelas	Precision	Recall	F1-Score
1	0,87	0,90	0,88
2	0,92	0,97	0,94
3	0,84	0,84	0,84
4	0,88	0,81	0,84
Avg	0,88	0,88	0,88

Berdasarkan *classification report*, kelas 2 memperoleh hasil paling tinggi dengan nilai *precision* sebesar 0,92, *recall* sebesar 0,97, dan *F1-score* sebesar 0,94. Nilai *recall* tersebut menunjukkan bahwa sebagian besar data yang sebenarnya termasuk kelas 2 berhasil dikenali oleh model. Kondisi ini menunjukkan bahwa karakteristik kata pada kelas tersebut relatif lebih mudah dibedakan dari kelas lainnya berdasarkan fitur yang digunakan.

Kelas 1 memperoleh *precision* sebesar 0,87, *recall* sebesar 0,90, dan *F1-score* sebesar 0,88. Hasil tersebut menunjukkan bahwa model mampu mengenali kelas 1 dengan cukup konsisten. Sementara itu, kelas 3 memperoleh *precision*, *recall*, dan *F1-score* sebesar 0,84. Nilai tersebut menunjukkan bahwa masih terdapat sejumlah data kelas 3 yang memiliki karakteristik teks yang mirip dengan kelas lainnya sehingga menyebabkan terjadinya kesalahan klasifikasi.

Kelas 4 memiliki *precision* sebesar 0,88, tetapi *recall* hanya mencapai 0,81 dengan *F1-score* sebesar 0,84. Perbedaan antara *precision* dan *recall* menunjukkan bahwa ketika model memprediksi suatu data sebagai kelas 4, prediksi tersebut relatif tepat, tetapi model masih melewatkan sebagian data yang sebenarnya termasuk kelas 4. Dengan demikian, permasalahan utama pada kelas 4 bukan hanya ketepatan prediksi, tetapi kemampuan model dalam menemukan seluruh data yang termasuk ke dalam kelas tersebut.

Secara keseluruhan, nilai rata-rata *precision*, *recall*, dan *F1-score* sebesar 0,88 menunjukkan bahwa model mempunyai kinerja yang relatif konsisten pada keempat kelas. Namun, perbedaan nilai antarkelas memperlihatkan bahwa karakteristik data tidak sepenuhnya seragam. Hasil ini juga memperlihatkan bahwa penggunaan TF-IDF belum sepenuhnya mengatasi permasalahan kemiripan kosakata antar kategori berita.

Hasil *classification report* menunjukkan bahwa performa model tidak hanya dapat dilihat dari nilai akurasi secara keseluruhan, tetapi juga dari kemampuan model pada masing-masing kelas. Nilai *precision*, *recall*, dan *F1-score* yang berada pada rentang 0,81 hingga 0,97 menunjukkan bahwa model masih mampu memberikan hasil klasifikasi yang cukup baik. Evaluasi menggunakan beberapa metrik tersebut penting karena setiap metrik memberikan informasi yang berbeda mengenai kesalahan prediksi model. Penelitian mengenai klasifikasi teks juga menggunakan *precision*, *recall*, dan *F1-score* untuk melihat kemampuan model dalam mengenali kategori teks secara lebih terperinci (Almazaydeh et al., 2023).


Nilai *precision* rata-rata sebesar 0,88 menunjukkan bahwa sebagian besar data yang diprediksi oleh model ke dalam suatu kelas memang sesuai dengan kelas tersebut. Sementara itu, nilai *recall* rata-rata sebesar 0,88 menunjukkan bahwa model mampu menemukan sebagian besar data yang sebenarnya termasuk dalam masing-masing kelas. Kesamaan nilai rata-rata antara *precision* dan *recall* menunjukkan bahwa model memiliki keseimbangan yang cukup baik antara ketepatan prediksi dan kemampuan menemukan data yang benar. Penggunaan TF-IDF dalam klasifikasi teks dapat membantu model memberikan bobot lebih besar pada kata-kata yang dianggap penting dalam membedakan suatu kategori.

Perbedaan hasil antar kelas dapat dipengaruhi oleh karakteristik kata yang terdapat pada masing-masing kategori berita. Kelas 2 memiliki *recall* paling tinggi, yaitu 0,97, sehingga sebagian besar data yang sebenarnya termasuk kelas tersebut berhasil dikenali. Sebaliknya, kelas 4 memiliki *recall* sebesar 0,81, yang menunjukkan masih terdapat data kelas 4 yang dikategorikan ke kelas lain. Kondisi tersebut dapat terjadi ketika beberapa berita memiliki kosakata yang saling beririsan sehingga fitur TF-IDF yang digunakan belum mampu membedakan konteks setiap berita secara sempurna. Penelitian terbaru mengenai klasifikasi berita dengan Naïve Bayes dan TF-IDF juga menjelaskan bahwa metode berbasis TF-IDF memiliki keterbatasan dalam menangkap hubungan semantik dan konteks kata secara mendalam .

Hasil penelitian ini juga menunjukkan bahwa penggunaan Naïve Bayes bersama TF-IDF masih relevan untuk digunakan pada permasalahan klasifikasi berita. Naïve Bayes bekerja dengan menghitung probabilitas suatu data berdasarkan karakteristik fitur yang terdapat pada teks. Ketika dikombinasikan dengan TF-IDF, kata-kata yang memiliki kemampuan membedakan antar kategori dapat menjadi fitur dalam proses klasifikasi. Penelitian pada klasifikasi berita menggunakan TF-IDF dan Multinomial Naïve Bayes menunjukkan bahwa pendekatan tersebut mampu menghasilkan performa klasifikasi yang cukup baik, dengan nilai *test accuracy* sebesar 90% serta rata-rata *F1-score* sebesar 0,87.

Berdasarkan keseluruhan hasil tersebut, model yang digunakan dalam penelitian ini sudah mampu melakukan klasifikasi terhadap empat kategori berita dengan performa yang relatif stabil. Nilai rata-rata *precision*, *recall*, dan *F1-score* sebesar 0,88 memperlihatkan bahwa model dapat mengenali pola pada data teks dengan cukup baik, meskipun masih terdapat kesalahan pada beberapa kategori, terutama kelas 4. Perbaikan selanjutnya dapat dilakukan dengan mengembangkan proses preprocessing, menggunakan kombinasi fitur seperti *n-gram*, atau mencoba metode representasi teks yang mampu menangkap hubungan antarkata dengan lebih baik. Penelitian tahun 2025 menunjukkan bahwa pengembangan fitur berbasis domain dan pemilihan fitur yang mempertimbangkan konteks dapat meningkatkan kemampuan klasifikasi dibandingkan penggunaan TF-IDF dasar (Zhang, 2025).

3.4. Confusion Matrix



Gambar 3.2 Visualisasi Confusion Matrix

Visualisasi *confusion matrix* menunjukkan distribusi hasil prediksi model pada masing-masing kelas. Prediksi yang berada pada diagonal utama menunjukkan data yang berhasil diklasifikasikan sesuai dengan kelas sebenarnya, sedangkan nilai di luar diagonal menunjukkan terjadinya kesalahan klasifikasi. Berdasarkan visualisasi tersebut, prediksi benar terlihat lebih dominan pada diagonal utama sehingga mendukung hasil akurasi sebesar 87,96%.

Kesalahan klasifikasi yang masih muncul terutama terjadi pada kelas 3 dan kelas 4. Kondisi tersebut menunjukkan bahwa terdapat kemiripan karakteristik teks antara kedua kelas. Kemiripan dapat berupa penggunaan kosakata yang sama, topik berita yang berdekatan, maupun pola penulisan yang serupa. Dalam kondisi seperti ini, Multinomial Naïve Bayes melakukan klasifikasi berdasarkan probabilitas kemunculan fitur sehingga kata yang muncul pada beberapa kategori dapat menyebabkan model memilih kelas yang kurang tepat.

Hasil penelitian ini menunjukkan bahwa penggunaan TF-IDF dengan kombinasi *unigram* dan *bigram* memberikan kontribusi dalam mengenali pola kata pada dokumen berita. *Unigram* memberikan informasi mengenai kata secara individual, sedangkan *bigram* menambahkan informasi mengenai pasangan kata. Meskipun demikian, pendekatan tersebut masih memiliki keterbatasan karena representasi TF-IDF lebih berfokus pada kemunculan fitur daripada hubungan makna antar kata. Oleh karena itu, teks yang memiliki kata-kata serupa tetapi memiliki konteks berbeda masih berpotensi diklasifikasikan ke dalam kelas yang salah.

Jika dibandingkan dengan penelitian terdahulu mengenai klasifikasi teks menggunakan algoritma Naïve Bayes, hasil akurasi sebesar 87,96% menunjukkan bahwa metode ini tetap mampu memberikan performa yang kompetitif pada klasifikasi berita. Perbedaan hasil antarpelitian tidak dapat dilepaskan dari karakteristik dataset, jumlah kategori, pembagian data latih dan data uji, tahap *preprocessing*, metode pembobotan fitur, serta parameter yang digunakan. Oleh karena itu, perbandingan akurasi tidak dapat digunakan secara langsung untuk menyatakan bahwa suatu penelitian lebih baik tanpa mempertimbangkan kondisi eksperimen yang digunakan.

Secara keseluruhan, hasil penelitian menunjukkan bahwa Multinomial Naïve Bayes dapat digunakan untuk melakukan klasifikasi kategori berita secara otomatis dengan akurasi 87,96% dan rata-rata *F1-score* sebesar 0,88. Temuan tersebut menjawab permasalahan penelitian mengenai kemampuan algoritma Naïve Bayes dalam mengelompokkan berita berdasarkan kategori. Namun, masih terdapat keterbatasan terutama dalam membedakan kategori yang memiliki kemiripan karakteristik teks. Pengembangan selanjutnya dapat dilakukan dengan membandingkan metode klasifikasi lain atau menggunakan representasi fitur yang mampu menangkap konteks dan hubungan semantik secara lebih baik.

4. Kesimpulan

Berdasarkan hasil penelitian, algoritma Naïve Bayes dapat digunakan untuk mengelompokkan berita berdasarkan kategori pada AG News Classification Dataset. Proses penelitian dilakukan melalui *preprocessing* teks dan pembobotan Term Frequency-Inverse Document Frequency (TF-IDF) sebelum data digunakan dalam klasifikasi. Hasil pengujian menunjukkan bahwa model memperoleh akurasi sebesar 87,96%, sehingga mampu mengklasifikasikan berita ke dalam kategori yang tersedia dengan cukup baik. Kombinasi *preprocessing*, TF-IDF, dan Naïve Bayes memberikan hasil yang sesuai untuk proses klasifikasi berita. Meskipun masih terdapat beberapa kesalahan klasifikasi, penerapan Naïve Bayes dan TF-IDF dapat menjadi pendekatan efektif dalam membantu proses klasifikasi berita secara otomatis berdasarkan karakteristik teks.

Reference

1. Afandi, F., & Kurniawan, R. (2025). Klasifikasi Teks Komentar Pengguna Aplikasi Access By Kai di Google Play Store Menggunakan Metode Naïve Bayes. *Bulletin of Computer Science Research*, 5(4), 456–472.
2. Agape, F. V., & Giri, G. A. V. M. (2025). Klasifikasi Berita Berdasarkan Kategori Menggunakan Multinomial Naïve Bayes dengan K-Cross Validation dan Seleksi Fitur Chi-Squared. *Jurnal Nasional Teknologi Informasi Dan Aplikasinya*, 3(2), 295–304.
3. Akbar, M. R., & Defit, S. (2024). Metode Support Vector Machine dan Naïve Bayes Untuk Analisis Sentimen Ibu Kota Nusantara. *Jurnal KomtekInfo*, 323–331.
4. Almazaydeh, L., Abuhelaleh, M. A., Al Tawil, A., & Elleithy, K. (2023). Clinical Text Classification with Word Representation Features and Machine Learning Algorithms. *Int. J. Online Biomed. Eng.*, 19(4), 65–76.
5. Amri, M. C., Atiqi, M. F., Talita, F., & Zufria, I. (2025). Implementasi Algoritma Naïve Bayes Untuk Klasifikasi Berita Online Terhadap Program Prioritas Pemerintah Kota Medan. *DEVICE: JOURNAL OF INFORMATION SYSTEM, COMPUTER SCIENCE AND INFORMATION TECHNOLOGY*, 6(2), 798–815.
6. Andzar, A. M. (2023). Penerapan Text Mining Dalam Klasifikasi Judul Skripsi Yang Diusulkan Mahasiswa Menggunakan Metode Naïve Bayes. 6, 184–196. <https://doi.org/10.57093/jisti.v6i2.174>

7. Arsyad, F., Hayatin, N., & Aditya, C. S. K. (2023). Deteksi Konten Hoax Pada Media Berita Indonesia Menggunakan Multinomial Naïve Bayes. *Jurnal Repositor*, 5(4).
8. Habib, S. M., Haerani, E., Gusti, S. K., & Ramadhani, S. (2022). Klasifikasi Berita Menggunakan Metode Naïve Bayes Classifier. 5(2), 248–258. <https://doi.org/10.32672/jnkti.v5i2.4191>
9. Hanum, A. R., Zetha, I. A., Fajrina, J. N., Wulandari, R. A., Putri, C., Andina, S. P., Yudistira, N., & Brawijaya, U. (2024). MENDETEKSI BERITA HOAKS PERFORMANCE ANALYSIS OF THE BERT TEXT CLASSIFICATION ALGORITHM. 11(3), 537–546. <https://doi.org/10.25126/jtiik938093>
10. Hendri Hartono, Alyauma Hajjah, Y. N. M. (2023). PENERAPAN METODE NAÏVE BAYES APPLICATION OF THE NAÏVE BAYES CLASSIFIER. 12(1), 37–46.
11. Ionendri, N. A., Candra, F., & Rizal, A. (2025a). JOURNAL OF APPLIED COMPUTER SCIENCE AND TECHNOLOGY (JACOST) News Classification using Natural Language Processing with TF-IDF and Multinomial Naïve Bayes. 6(1), 37–45.
12. Ionendri, N. A., Candra, F., & Rizal, A. (2025b). News classification using natural language processing with tf-idf and multinomial naive bayes. *Journal of Applied Computer Science and Technology*, 6(1), 37–45.
13. Lestari, N., Riza, O. S., Ardinal, R., Studi, P., Informasi, S., Islam, U., Imam, N., Padang, B., Gadang, B., Tangah, K. K., Padang, K., & Barat, S. (2023). Implementation Of Text Mining And Pattern Discovery With Naive Bayes Algorithm For Classification Of Text Documents. 14(x), 88–102.
14. Mardiana, A., & Prihartono, W. (2025). RANCANG BANGUN SISTEM KLASIFIKASI JUDUL BERITA ONLINE BAHASA INDONESIA BERBASIS WEB MENGGUNAKAN ALGORITMA NAÏVE BAYES. *Journal of Computer Science and Artificial Intelligence (JCSAI)*, 2(6).
15. Mardiana, A., Prihartono, W., Studi, P., Informatika, M., Studi, P., & Akuntansi, K. (2025). RANCANG BANGUN SISTEM KLASIFIKASI JUDUL BERITA ONLINE BAHASA INDONESIA BERBASIS WEB MENGGUNAKAN ALGORITMA. 06(02), 2–6. <https://doi.org/10.32485/jcsai.JOURNAL>
16. Pranata, A., Rudiman, R., & Verdikha, N. A. (2024). Klasifikasi Teks Quick Count Pemilihan Presiden 2024 pada Twitter menggunakan Metode TF-IDF dan Naive Bayes. *Jurnal Informatika Terpadu*, 10(2), 93–100.
17. Prasetya, F. (2022). Analisis Data Mining Klasifikasi Berita Hoax COVID 19 Menggunakan Algoritma Naive Bayes. 4(September), 132–139. <https://doi.org/10.30865/json.v4i1.4852>
18. Purnama, A. A., & Sipayung, Y. R. (2025). Sentiment Analysis of Public Service Using Naïve Bayes Classifier. 7(3), 2439–2457. <https://doi.org/10.51519/journalisi.v7i3.1207>
19. Rozi, M. F., Siregar, R., & Syahputri, N. I. (2023). Penerapan Data Mining Menggunakan Metode Naive Bayes Untuk Klasifikasi Data Penentuan Hasil Penjualan Dalam Strategi Pemasaran. 2(2), 444–454.
20. Selawati, A. (2025). BULLETIN OF COMPUTER SCIENCE RESEARCH Analisis Sentimen Berita Online Terhadap Transportasi Online di Indonesia dengan Metode Naïve Bayes Classifier , Support Vector Machine. 5(2), 105–111. <https://doi.org/10.47065/bulletincsr.v5i2.477>
21. Tejawati, A., Septiarini, A., Rismawati, R., & Puspitasari, N. (2023). Comparison of K-Nearest Neighbor and Naive Bayes Methods for Classification of News Content. *Jurnal Teknik Informatika (Jutif)*, 4(2), 401–412.
22. Zhang, L. (2025). Features extraction based on Naive Bayes algorithm and TF-IDF for news classification. *PLoS One*, 20(7), e0327347.